



Red neuronal artificial para la predicción de mortalidad de pacientes con enfermedad renal crónica

An artificial neural network for the prediction of mortality in patients with chronic kidney disease

Sergio Orlando Escalona González^{1*} <https://orcid.org/0000-0003-4261-6842>

Yailé Caballero Mota² <https://orcid.org/0000-0002-6725-5812>

Yanela Rodríguez Álvarez² <https://orcid.org/0000-0003-2232-2265>

Mirna León Acebo¹ <https://orcid.org/0000-0001-5652-8080>

Zoraida Caridad González Milán^{1,3} <https://orcid.org/0000-0002-4092-9389>

Beatriz Ricardo Paez^{1,3} <https://orcid.org/0000-0003-0204-1845>

Katiuska Danay Rodríguez Espinosa^{1,3} <https://orcid.org/0000-0001-5172-4701>

¹Universidad de Ciencias Médicas de Las Tunas. Facultad de Ciencias Médicas Dr. "Zoilo Enrique Marinello Vidaurreta". Las Tunas, Cuba.

²Universidad de Camagüey "Ignacio Agramonte y Loynaz". Camagüey, Cuba.

³Hospital General Docente Dr. "Ernesto Guevara de la Serna". Las Tunas, Cuba.

*Autor para la correspondencia. Correo electrónico: sernephron96@gmail.com

RESUMEN

Introducción: La mortalidad temprana en los pacientes con enfermedad renal crónica representa un gran problema de salud, por lo que el diseño de modelos pronósticos novedosos constituye una prioridad.

Objetivo: Diseñar una red neuronal artificial para la predicción de mortalidad en pacientes con enfermedad renal crónica en hemodiálisis.

<http://scielo.sld.cu>

<https://revmedmilitar.sld.cu>



Métodos: Se realizó un estudio analítico, de cohorte prospectivo, en pacientes con enfermedad renal crónica en hemodiálisis durante el período del 1 de enero de 2013 al 31 de diciembre de 2017. Se analizaron un total de 36 atributos en 392 pacientes. Se utilizó el perceptrón multicapa para el diseño de una red neuronal artificial compuesta por 12 variables. Finalmente, se evaluó la tabla de clasificación, la capacidad discriminatoria del algoritmo y la importancia normalizada de las variables pronósticas.

Resultados: La red neuronal artificial presentó porcentajes globales de clasificación correcto de un 96,3 % en la muestra de entrenamiento y un 96,7 % en la muestra de validación. La capacidad discriminatoria fue muy buena, área COR de 0,989. Las variables pronósticas de mortalidad de mayor importancia normalizada fueron la enfermedad cardiovascular, la albúmina y la sepsis.

Conclusiones: La red neuronal artificial contribuye a la estratificación del riesgo de mortalidad de los pacientes con enfermedad renal crónica en hemodiálisis. El modelo presenta buena capacidad discriminatoria e indicadores de eficacia estadística. Las variables pronósticas identificadas son de fácil determinación e interpretación, por lo que se considera como una herramienta predictiva de útil implementación en la toma de decisiones médicas en el ámbito clínico.

Palabras clave: aprendizaje automático; enfermedad renal crónica; hemodiálisis; inteligencia artificial; mortalidad; redes neuronales de la computación.

ABSTRACT

Introduction: Early mortality in patients with chronic kidney disease represents a major health problem, which is why the design of novel prognostic models is a priority.

Objective: Design an artificial neural network for the prediction of mortality in patients with chronic kidney disease on hemodialysis.

Methods: A prospective cohort analytical study was conducted in patients with chronic kidney disease on hemodialysis during the period from January 1, 2013 to December 31, 2017. A total of 36 attributes were analyzed in 392 patients. The multilayer perceptron was used to design an artificial neural network composed of 12 variables. Finally, the classification table, the discriminatory capacity of the algorithm and the normalized importance of the prognostic variables were evaluated.



Results: The artificial neural network presented overall correct classification percentages of a 96.3% in the training sample and a 96.7% in the validation sample. The discriminatory capacity was very good, area ROC of 0.989. The most important normalized predictors of mortality were cardiovascular disease, albumin, and sepsis.

Conclusions: The artificial neural network contributes to the stratification of mortality risk of patients with chronic kidney disease on hemodialysis. The model has good discriminatory capacity and indicators of statistical effectiveness. The prognostic variables identified are easy to determine and interpret, which is why it is considered a predictive tool with useful implementation in medical decision making in the clinical setting.

Keywords: artificial intelligence; chronic kidney disease; computing neural networks; hemodialysis; machine learning; mortality.

Recibido: 04/02/2024

Aprobado: 13/06/2024

INTRODUCCIÓN

La enfermedad renal crónica (ERC) es una enfermedad crónica no trasmisible de gran crecimiento en los últimos años y se estima que para el 2040 ocupe la quinta causa de años de vida potencialmente perdidos. La prevalencia de ERC en el mundo es de 850 millones de pacientes, de los cuales, cuatro millones reciben terapias de reemplazo renal para una tasa bruta de 298,4 pacientes por millón de habitantes.⁽¹⁾ En Cuba, durante el año 2022 la ERC fue la causa número 13 de mortalidad. Se reportaron 1 278 muertes, 170 menos que el año 2021, para una tasa bruta de 11,5.⁽²⁾ A pesar de la ligera disminución en cuanto a la incidencia de muertes por esta causa, la ERC continúa como una de las principales enfermedades crónicas no trasmisibles que provoca mayores decesos.

El procesamiento de grandes cantidades de datos es un desafío para la humanidad. En aras de mejorar esta limitación, la inteligencia artificial (IA) utiliza técnicas de cálculo avanzadas para procesar cualquier

<http://scielo.sld.cu>

<https://revmedmilitar.sld.cu>



tipo de dato y permitir la toma de decisiones. En la actualidad se necesita de herramientas y técnicas de gestión de datos con capacidad de extraer información de forma oportuna y confiable. El análisis inteligente de estos datos depende del desarrollo de modelos novedosos. En particular, el aprendizaje automático tiene la capacidad de aprender y mejorar el rendimiento sin la necesidad de ser programado de forma específica, este logra la automatización continua de los procesos.^(3,4)

Entre los años 1990 y 2019 la IA en el campo de la nefrología fue poco estudiada. En este período solamente se visualizaron 218 artículos científicos que hacían referencia a las enfermedades renales y el empleo de algoritmos de la IA. Del total de estudios mencionados, solo 8 artículos trataban la mortalidad en la ERC.⁽⁵⁾ Recientemente, existe un crecimiento vertiginoso en el interés de integrar diferentes herramientas de la IA en la ERC.

Existen diferentes algoritmos de la IA para la solución de problemas de regresión y clasificación. Las redes neuronales artificiales (RNA) es uno de los métodos de aprendizaje automático de mayor complejidad y mejores rendimientos.⁽⁶⁾

Las RNA poseen numerosas ventajas para la predicción de mortalidad en pacientes con ERC en hemodiálisis (HD) con respecto a otros algoritmos de la IA: mayor capacidad de aprendizaje y adaptación a tendencias complejas en los datos, mejor manejo de grandes cantidades de datos, identificación de relaciones no lineales para tareas específicas y mayor precisión y eficacia en la identificación de patrones para la toma de decisiones clínicas.

Teniendo en cuenta los comentarios anteriores, el objetivo de la presente investigación es diseñar una red neuronal artificial para la predicción de mortalidad en pacientes con enfermedad renal crónica en hemodiálisis.

MÉTODOS

Contexto y clasificación de la investigación

Se realizó un estudio analítico, de cohorte prospectivo en pacientes con enfermedad renal crónica en hemodiálisis en el Hospital General Docente Dr. "Ernesto Guevara de la Serna" de Las Tunas, Cuba, que



comenzaron la terapia de reemplazo renal durante el período del 1 de enero de 2013 al 31 de diciembre de 2017.

Población y muestra

La población de estudio estuvo constituida por 439 pacientes con ERC en HD que comenzaron la terapia de reemplazo renal durante el período declarado anteriormente. La muestra quedó constituida por los 392 pacientes que cumplieron con los criterios de inclusión y exclusión.

Para calcular el número de pacientes fallecidos, que se necesitaban incluir en el diseño del modelo predictivo para realizar validación, se utilizó la fórmula para muestras finitas o conocidas:⁽⁷⁾

$$n = \frac{N * Z^2 * p * q}{e^2 (N - 1) + Z^2 * p * q}$$

Donde “n” representó el total de pacientes con ERC en HD necesarios a incluir en la muestra, Z= 1,96 para un nivel de confianza de un 95 %, con un máximo error permisible del 5 % (e= 0,05). El valor de p= 0,15 y q= 0,85 se planteó teniendo en cuenta una investigación que informó que la mortalidad anual de los pacientes con ERC en HD fue de 15,2 %.⁽⁸⁾ Finalmente, se obtuvo un valor n= 136; pero se incluyeron 123 pacientes que representó el total de fallecidos.

Criterios de inclusión

Se incluyeron los pacientes mayores de 18 años de edad con ERC en HD que comenzaron la terapia de reemplazo renal durante el período e institución declarados. Se excluyeron los pacientes que recuperaron la función renal y salieron del programa de HD y aquellos que se les realizó trasplante renal.

Variables en la investigación

Se analizaron un total de 36 atributos divididos en variables epidemiológicas, clínicas/paraclínicas y dependientes de la HD. En el caso de las variables paraclínicas, el valor que se tomó para la investigación fue la primera determinación analítica realizada previa a la primera sesión de HD. Las variables con datos faltantes fueron la dislipidemia, albúmina, urea, calcio, colesterol y potasio; estas fueron menores al 5 %. Se realizó imputación con el valor de la mediana en el caso de las variables cuantitativas y la moda para la variable cualitativa.



A continuación, se muestra la operacionalización de las variables y se mencionan las categorías que se tuvieron en cuenta para el análisis de la RNA.

Variable dependiente: mortalidad.

Variables independientes:

- Edad: según los años cumplidos al inicio de la investigación. Para el análisis de la RNA se consideraron 2 categorías, (0) igual o menor a 65 años, (1) mayor a 65 años.⁽⁹⁾
- Enfermedad cardiovascular: si el paciente presentó enfermedad coronaria, insuficiencia cardíaca o arritmia. Para el análisis de la RNA se consideraron 2 categorías, (0) ausencia, (1) presencia.⁽¹⁰⁾
- Tabaquismo: si el paciente en el momento del estudio fumaba; (0) no fumador, (1) fumador.⁽¹¹⁾
- Dislipidemia: si el paciente tenía el antecedente o si presentó cifras de colesterol superior a 5,7 mmol/L o triglicéridos superior a 1,7 mmol/L. Para el análisis de la RNA se consideraron 2 categorías; (0) ausencia, (1) presencia.⁽¹²⁾
- Desnutrición: si el índice de masa corporal era inferior a 18,5 kg/m². El cálculo se realizó según la fórmula de Quetelet,⁽¹³⁾ (0) ausencia, (1) presencia.
- Atención previa: si el paciente recibió atención previa sistemática en consultas de atención al paciente con ERC en la atención primaria de salud; (0) recibió, (1) no recibió.⁽¹⁴⁾
- Inicio tardío HD: si el paciente comenzó la HD en un período mayor de 6 meses de indicada la terapia de reemplazo renal; (0) no comenzó tardíamente, (1) sí comenzó tardíamente.⁽¹⁵⁾
- Ganancia de peso interdiálisis excesiva: si el paciente tuvo un aumento de peso interdiálisis mayor que el 4,5 % del peso corporal total; (0) no tuvo, (1) sí tuvo.⁽¹⁶⁾

Seguimiento de la cohorte

La cohorte fue seguida durante un año de forma semanal en la que se analizaron variables clínicas y paraclínicas y se determinó si existía aparición de la variable dependiente. Se definió como variable



dependiente a la muerte por cualquier causa de los pacientes con ERC en HD en el período e institución declarados.

Procesamiento estadístico

Los datos obtenidos fueron almacenados y procesados en el *software Statical Package for Social Sciences, SPSS* versión 20 para *Windows*.

Para determinar la distribución normal o no de las variables cuantitativas se aplicó el test Kolmogorov Smirnov. Las variables cuantitativas que presentaron distribución normal se expresaron en media y desviación estándar y sus medias fueron comparadas a través del test estadístico *t* de Student. Las variables que no presentaron distribución normal se expresaron en mediana y rango intercuartil y se realizó la comparación con el test U de Mann Whitney.

Para determinar las diferencias entre los grupos establecidos según variables cualitativas se utilizó el test estadístico *ji* cuadrado basado en su hipótesis de homogeneidad.⁽¹⁷⁾

Diseño de la red neuronal artificial

Para reunir las variables que debían añadirse a la RNA se tuvo en cuenta la regla de 10 eventos de la variable dependiente (fallecidos) por cada variable independiente que se añadió a la RNA.⁽¹⁸⁾

Para la selección de las variables independientes se realizó una búsqueda en 4 bases de datos: Pubmed, Scopus, Sciendirect y Google Scholar. Las estrategias de búsquedas fueron “*artificial intelligence OR machine learning AND mortality AND end stage renal disease AND hemodialysis*”. Posteriormente, se identificaron 12 potenciales factores pronósticos que se añadieron al análisis de la RNA.^(1,3,6)

Se creó una RNA mediante el perceptrón multicapa, programada con el *software SPSS* versión 20. La muestra se particionó en el 70 % para el entrenamiento y el 30 % para la prueba.⁽¹⁹⁾

En cuanto a la arquitectura de la RNA, las capas de entradas estuvieron conformadas por los 12 potenciales factores pronósticos identificados. Presentó 2 capas ocultas con 5 neuronas en cada capa, este diseño fue el que mostró mejor rendimiento.⁽²⁰⁾ La capa de salida representó la variable dependiente (“sí mortalidad” o “no mortalidad”).

Finalmente, se presentó el esbozo de la RNA, así como la tabla de clasificación de este algoritmo. Su capacidad discriminatoria se analizó mediante el área bajo la curva de características operativas del



receptor o estadístico C. Para mejorar la explicabilidad⁽²¹⁾ del modelo se presentó además la importancia normalizada de las variables independientes.

Aspectos éticos

Se cumplió con las normas éticas de la Declaración de Helsinki. Se utilizaron las historias clínicas y otros documentos que pudieran ofrecer datos de relevancia para realizar el estudio. La investigación fue aprobada por el comité de ética provincial (Se anexa documento de aprobación en fichero complementario).

RESULTADOS

Como se muestra en la tabla 1 se analizaron 392 pacientes. La media de edad global fue de 56,378 años (DE: 13,9559), la media de edad fue significativamente mayor en el grupo de los pacientes fallecidos ($p=0,000$); predominó el sexo masculino (68,1 %). En cuanto a los antecedentes, el 50,3 % de los pacientes tenían hipertensión arterial y el 26,5 % diabetes mellitus. La enfermedad cardiovascular ($p=0,001$), la dislipidemia ($p=0,000$) y la diabetes mellitus ($p=0,002$) resultaron variables estadísticamente significativas.

En cuanto a las variables derivadas de los exámenes complementarios, la hemoglobina, albúmina, urea, creatinina, filtrado glomerular, glucemia, colesterol y potasio arrojaron resultados estadísticamente significativos.

El inicio tardío en la hemodiálisis, la ganancia de peso interdialítica excesiva y la sepsis también fueron variables estadísticamente significativas en el análisis univariado.



Tabla 1 - Distribución de los pacientes según características epidemiológicas, clínicas y exámenes complementarios

Variables	Total n= 392	Fallecidos n ₁ = 123	Vivos n ₂ = 269	P
Sexo masculino [n, (%)]	267 (68,1)	81 (65,9)	186 (69,1)	0,516
Edad (media, DE)	56,378 ±13,9559	64,276 ±11,6923	52,766 ±13,4237	0,000*
Enfermedad cardiovascular [n, (%)]	83 (21,2)	68 (55,3)	15 (5,6)	0,000*
Tabaquismo [n, (%)]	79 (20,9)	25 (20,7)	54 (21,0)	0,938
Desnutrición [n, (%)]	101 (25,8)	38 (30,9)	63 (23,4)	0,116
Dislipidemia [n, (%)]	63 (16,1)	42 (34,1)	21 (7,8)	0,000*
Diabetes mellitus [n, (%)]	104 (26,5)	45 (36,6 %)	59 (21,9 %)	0,002*
Hipertensión arterial [n, (%)]	197 (50,3)	68 (55,3 %)	129 (48,0 %)	0,178
Hemoglobina [mediana, (intercuartil)]	11 (2,4)	10 (2)	11 (2)	0,000 ^b *
Albumina [mediana, (intercuartil)]	38 (9)	29 (14,25)	41 (8)	0,000*
Urea [mediana, (intercuartil)]	16 (4)	17,75 (2,52)	15,9 (3,6)	0,000*
Creatinina [mediana, (intercuartil)]	968 (240)	976 (162,25)	969 (309)	0,000*
Filtrado glomerular [mediana, (intercuartil)]	6 (2,4)	5,35 (1,87)	6 (2,6)	0,000*
Ácido úrico [mediana, (intercuartil)]	345 (120)	355 (121)	354 (106,5)	0,408
Glucemia [mediana, (intercuartil)]	4,2 (1,6)	4 (1,32)	4,6 (1,8)	0,000*
Colesterol [mediana, (intercuartil)]	4 (1,8)	4,6 (1,20)	3,8 (1,75)	0,000*
Potasio [mediana, (intercuartil)]	4,6 (1)	5,4 (1,6)	4,5 (0,75)	0,000*
Atención previa [n, (%)]	236 (62,8)	71 (59,7)	165 (64,2)	0,397
Inicio tardío HD [n, (%)]	69 (17,6)	43 (35,0)	26 (9,7)	0,000*
Catéter centrovenoso [n, (%)]	191 (48,7)	62 (50,4)	129 (48,0)	0,652
GPIE [n, (%)]	73 (18,6)	53 (43,1)	20 (7,4)	0,000*
Hepatitis adquirida [n, (%)]	106 (27,0)	29 (23,6)	77 (28,6)	0,296
Sepsis [n, (%)]	61 (15,6)	48 (39,0)	13 (4,8)	0,000*

DE: desviación estándar; TAS: tensión arterial sistólica; TAD: tensión arterial diastólica; HD: hemodiálisis; EPOC: enfermedad pulmonar obstructiva crónica; ERPAD: enfermedad renal poliquística autosómica dominante; ERPAD: enfermedad renal poliquística autosómica dominante; GPIE: ganancia de peso interdialítica excesiva. * Estadísticamente significativo.

La tabla 2 muestra la clasificación global del modelo pronóstico donde se puede apreciar la precisión de las predicciones hechas por la RNA: 97,8 % en los pacientes vivos, 93,3 % en los pacientes fallecidos y 96,7 % de forma general, en la muestra de validación.



Tabla 2 – Clasificación de la RNA

Muestra	Observado	Pronóstico		
		No	Sí	Porcentaje correcto
Entrenamiento	No	171	7	96,1
	Sí	3	90	96,8
	Porcentaje global	64,2	35,8	96,3
Validación	No	89	2	97,8
	Sí	2	28	93,3
	Porcentaje global	75,2 %	24,8 %	96,7

La figura 1 muestra el esbozo de la RNA, este modelo se ejecutó de forma automática en dos muestras: el entrenamiento 271 pacientes (69,1 %) y la prueba 121 pacientes (30,9 %).

Por otra parte, la figura 2 revela la capacidad discriminatoria de la RNA y muestra un área bajo la curva del estadístico C de 0,989. Teniendo en cuenta que este valor fue superior a 0,70 se puede considerar que la RNA tiene valor predictivo significativo.

En la figura 3 se presenta la importancia normalizada de las variables independientes y se aprecia como la enfermedad cardiovascular, la albúmina, y la sepsis presentaron importancia normalizada mayor al 70 %, por lo que fueron las variables más importantes que influyeron en la mortalidad de los pacientes con ERC en HD.

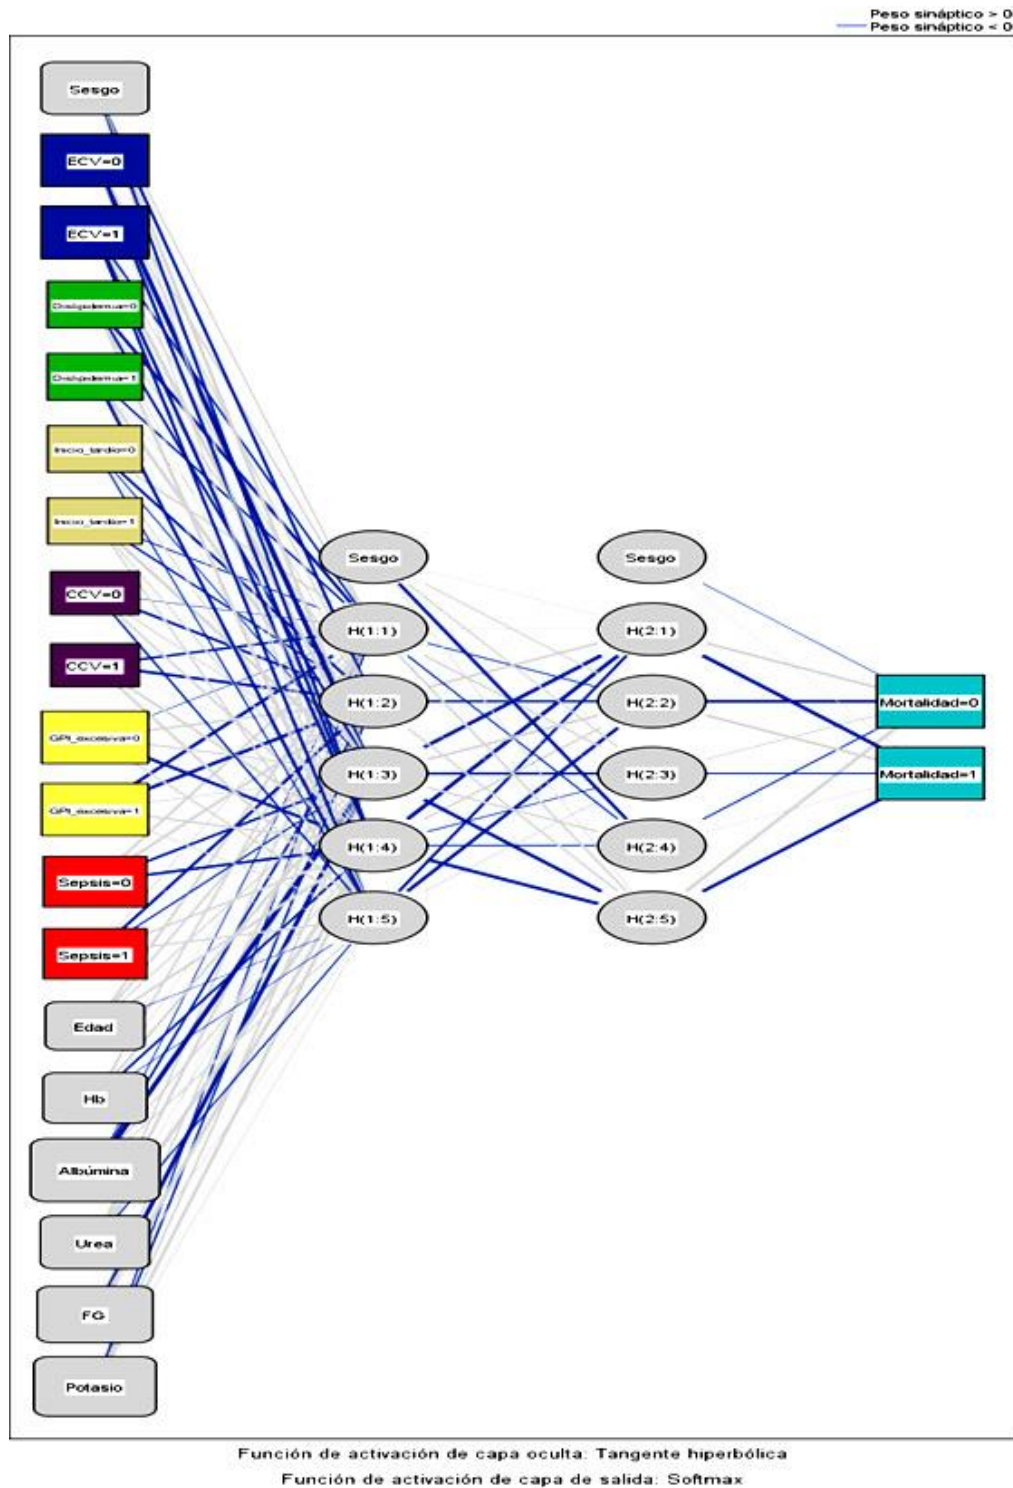


Fig. 1 – Esbozo de la RNA.

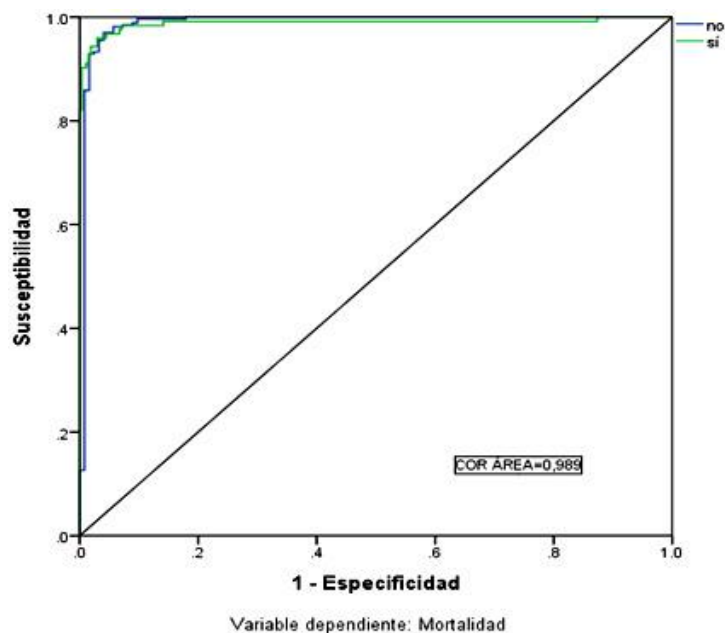


Fig. 2 – Capacidad discriminatoria de la RNA.

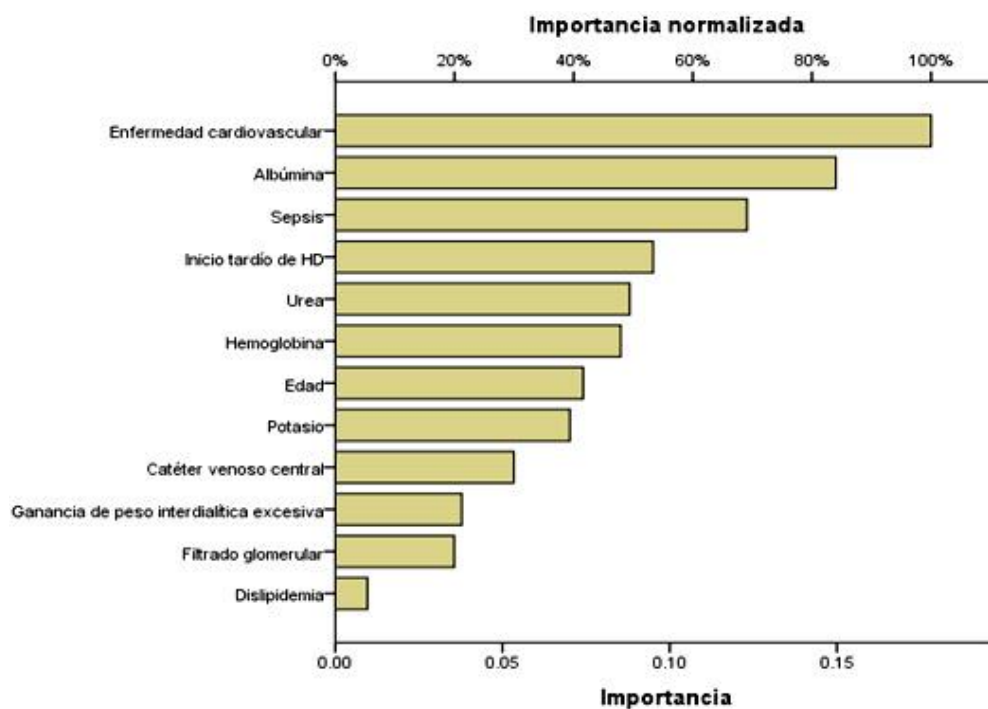


Fig. 3 – Importancia normalizada de las variables independientes.



DISCUSIÓN

El aprendizaje automático es un subdominio poderoso de la IA que permite el desarrollo de tecnologías con aplicaciones beneficiosas. La capacidad de los sistemas automáticos para la solución avanzada de problemas se sustenta en modelos analíticos que propician las predicciones basadas en datos históricos que permiten mejorar el rendimiento a partir de la experiencia.

Elbasaha A y otros⁽²²⁾ analizaron 6 000 sesiones de hemodiálisis en 215 pacientes con ERC. Los datos fueron recolectados durante 24 semanas para desarrollar un modelo de RNA para predecir complicaciones intradialíticas y mortalidad. El modelo presentó una precisión del 96 % y área bajo la curva del estadístico C de 99,3; lo que permitió concluir que la RNA fue eficaz en el pronóstico del desenlace final de los pacientes.

Dentro de este orden de ideas, *Singh V* y otros⁽²³⁾ analizaron 24 cualidades clínicas de 400 pacientes con ERC y afirman que el modelo neuronal profundo superó a los clasificadores basados en máquinas de vectores de soporte, k-vecinos más cercanos, regresión logística, bosque aleatorio y bayesianos ingenuos, al lograr un 100 % en la precisión.

Según las investigaciones citadas, las RNA presentan notables indicadores estadísticos para la predicción de mortalidad en pacientes con ERC en HD. En el presente estudio, el modelo de RNA diseñado presentó un porcentaje global correcto de un 96,3 % y un 96,7 % en las muestras de entrenamiento y validación, respectivamente. Además, se obtuvo un área bajo la curva del estadístico C de 0,989 que respalda al modelo con excelente capacidad de discriminación.

En la presente investigación se analizó la importancia normalizada de las variables independientes, este paso favorece la identificación de las variables pronósticas según relevancia. El modelo de RNA mostró a la enfermedad cardiovascular, la albúmina y la sepsis como los atributos de mayor importancia en la predicción de mortalidad (importancia normalizada > 70 %).

La enfermedad cardiovascular es la primera causa de mortalidad en los pacientes con ERC. Los pacientes en HD presentan calcificación vascular, aterosclerosis avanzada y rigidez valvular. Estos fenómenos



son capaces de favorecer el desarrollo de hipertrofia ventricular izquierda, insuficiencia cardíaca, arritmias y paro cardíaco.⁽²⁴⁾

En cuanto a los niveles de albúmina, un estudio realizado en pacientes con ERC en HD en Las Tunas entre los años 2016 y 2019 reportó que la albúmina menor a 35 g/L fue un factor pronóstico de mortalidad ($p= 0,000$; *hazard ratio*: 3,468; IC: 1,760-5,879).⁽²⁵⁾

La sepsis es una variable que se asocia frecuentemente a la mortalidad en los pacientes en HD. *Hong Y* y otros⁽²⁶⁾ realizaron un estudio que incluyó 149 947 pacientes prevalentes en diálisis durante los años 2001 y 2019. En el transcurso, la mediana de seguimiento fue de 34,8 meses, fallecieron 30 852 pacientes y la sepsis constituyó la segunda variable de importancia asociada a la mortalidad, solamente la enfermedad cardiovascular presentó mayor incidencia.

Esta investigación constituye el primer reporte en Cuba del diseño de una RNA para la predicción de mortalidad en pacientes con ERC en HD. La RNA diseñada puede implementarse para la prevención y la intervención en la mortalidad, con implicaciones a corto, mediano y largo plazo en el pronóstico de cohortes generales de este tipo de pacientes teniendo en cuenta que es un modelo objetivo, aplicable, reproducible y se puede generalizar en otros contextos.

La red neuronal artificial contribuye a la estratificación del riesgo de mortalidad de los pacientes con enfermedad renal crónica en hemodiálisis. El modelo presenta buena capacidad discriminatoria e indicadores de eficacia estadística. Las variables pronósticas identificadas son de fácil determinación e interpretación, por lo que se considera como una herramienta predictiva de útil implementación en la toma de decisiones médicas en el ámbito clínico actual.

Se recomienda realizar investigaciones de validación externa de la red neuronal propuesta en cohortes con mayores muestras de estimación.



REFERENCIAS BIBLIOGRÁFICAS

1. Bello A, Okpechi I, Osman M, Cho Y, Htay H, Jha V, et al. Epidemiology of haemodialysis outcomes [Internet]. Nature Reviews Nephrology. 2022; 18(6):378-95. DOI: [10.1038/s41581-022-00542-7](https://doi.org/10.1038/s41581-022-00542-7)
2. Anuario Estadístico de Salud, 2022. Ministerio de Salud Pública. Dirección de Registros médicos y Estadísticas de salud [Internet]. La Habana, 2023 [acceso: 15/11/2023]. Disponible en: <http://bvscuba.sld.cu/anuario-estadistico-de-cuba/>
3. Koteluk O, Wartecki A, Mazurek S, Kołodziejczak I, Mackiewicz A. How Do Machines Learn? Artificial Intelligence as a New Era in Medicine [Internet]. J Pers Med. 2021; 11(1):1-22. DOI: [10.3390/jpm11010032](https://doi.org/10.3390/jpm11010032)
4. Sarker IH. Machine learning: algorithms, real-world applications and research directions [Internet]. SN Computer Science. 2021; 2(3):1-21. DOI: [10.1007/s42979-021-00592-x](https://doi.org/10.1007/s42979-021-00592-x)
5. Park S, Park BS, Lee YJ, Kim H, Park JH, Ko J, et al. Artificial intelligence with kidney disease A scoping review with bibliometric analysis, PRISMA-ScR [Internet]. Medicine. 2021; 100(14):e25422. DOI: [10.1097/MD.00000000000025422](https://doi.org/10.1097/MD.00000000000025422)
6. Khazaei S, Najafi Ghobadi S, Ramezani Doroh V. Construction data mining methods in the prediction of death in hemodialysis patients using support vector machine, neural network, logistic regression and decision tree [Internet]. J Prev Med Hyg. 2021; 62(1):E222-30. DOI: [10.15167/2421-4248/jpmh2021.62.1.1837](https://doi.org/10.15167/2421-4248/jpmh2021.62.1.1837)
7. Gamboa Graus ME. Estadística aplicada a la investigación educativa [Internet]. Revista Dilemas Contemporáneos: Educación, política y valores. 2018 [acceso:15/11/2023]; 5(2):1-32. Disponible en: <http://www.dilemascontemporaneoseducacionpoliticayvalores.com/index.php/dilemas/article/view/427/443>
8. de Arriba G, Gutiérrez Ávila G, Torres Guinea M, Moreno Alia I, Herruzo JA, Rincón Ruiz B, et al. La mortalidad de los pacientes en hemodiálisis está asociada con su situación clínica al comienzo del tratamiento [Internet]. Nephrology. 2021; 41(4):461-6. DOI: [10.1016/j.nefro.2020.11.006](https://doi.org/10.1016/j.nefro.2020.11.006)



9. Ruperto M, Barril G. Nutritional status, body composition, and inflammation profile in older patients with advanced chronic kidney disease stage 4-5: A case control study [Internet]. *Nutrients*. 2022; 14(17):3650. DOI: [10.3390/nu14173650](https://doi.org/10.3390/nu14173650)
10. Matsushita K, Ballew S, Wang A. Epidemiology and risk of cardiovascular disease in populations with chronic kidney disease [Internet]. *Nature Reviews Nephrology*. 2022; 18(11):696-707. DOI: [10.1038/s41581-022-00616-6](https://doi.org/10.1038/s41581-022-00616-6)
11. Lee S, Kang S, Joo Y. Smoking, smoking cessation, and progression of chronic kidney disease: results from KNOW-CKD study [Internet]. *Nicotine & Tobacco Research*. 2021; 23(1):92-8. DOI: [10.1093/ntr/ntaa071](https://doi.org/10.1093/ntr/ntaa071)
12. Liang X, Ye M, Tao M. The association between dyslipidemia and the incidence of chronic kidney disease in the general Zhejiang population: a retrospective study [Internet]. *BMC Nephrol*. 2020; 21(252):1-9. DOI: [10.1186/s12882-020-01907-5](https://doi.org/10.1186/s12882-020-01907-5)
13. Feng-Ching S, Yi-Wen Ch, Mei-Chuan K. U-shaped association between waist-to-hip ratio and all-cause mortality in stage 3-5 chronic kidney disease patients with body mass index paradox [Internet]. *J Pers Med*. 2021; 11(12):1355. DOI: [10.3390/jpm11121355](https://doi.org/10.3390/jpm11121355)
14. Jan M, Deseo J. Balancing Nephrology Referrals With Nephrologist Capacity to Decrease Emergency Dialysis Starts [Internet]. *Ki Reports*. 2020; 6(1):7-10. DOI: [10.1016/j.ekir.2020.11.014](https://doi.org/10.1016/j.ekir.2020.11.014)
15. Hsu C, Parikh R, Pravoverov L. Implication of trends in timing of dialysis initiation for incidence of end-stage kidney disease [Internet]. *JAMA Intern Med*. 2020; 180(12):1647-54. DOI: [10.1001/jamainternmed.2020.5009](https://doi.org/10.1001/jamainternmed.2020.5009)
16. Bossola M, Pepe G, Antocicco M, Severino A, Di Stasio E. Interdialytic weight gain and educational/cognitive, counseling/behavioral and psychological/affective interventions in patients on chronic hemodialysis: a systematic review and meta-analysis [Internet]. *Journal of Nephrology*. 2022; 35(1):1973–83. DOI: [10.1007/s40620-022-01450-6](https://doi.org/10.1007/s40620-022-01450-6)
17. Romero J, León E. Algoritmos en el manejo de muestras y variables en bioestadística [Internet]. 16 de Abril. 2018 [acceso:15/11/2023]; 57(269):177-194. Disponible en: https://rev16deabril.sld.cu/index.php/16_04/article/view/770



18. Rossello X, González-Del-Hoyo M. Análisis de supervivencia en investigación cardiovascular (I): lo esencial [Internet]. *Rev Esp Cardiol*. 2022; 75(1):67-76. DOI: [10.1016/j.recesp.2021.05.017](https://doi.org/10.1016/j.recesp.2021.05.017)
19. Schlüter M, Nlte G, Murtovi A, Steffen B. Towards rigorous understanding of neural networks via semantics-preserving transformations [Internet]. *International Journal on Software Tools for Technology Transfer*. 2023; 25(3):301-27. DOI: [10.1007/s10009-023-00700-7](https://doi.org/10.1007/s10009-023-00700-7)
20. Celard P, Lorenzo Iglesias E, Sorribes-Fernández JM, Romero R, Seara Vieira A, Borrajo L. A survey on deep learning applied to medical images: from simple artificial networks to generative models. [Internet]. *Neural Computing and Applications*. 2023; 35(3):2291-323. DOI: [10.1007/s00521-022-07953-4](https://doi.org/10.1007/s00521-022-07953-4)
21. Bai Q, Su C, Tang W, Li Y. Machine learning to predict end stage kidney disease in chronic kidney disease [Internet]. *Scientific Reports*. 2022; 12(1):8377. DOI: [10.1038/s41598-022-12316-z](https://doi.org/10.1038/s41598-022-12316-z)
22. Elbasha A, Naga Y, Othman M, Moussa N, Elwakil H. A step towards the application of an artificial intelligence model in the prediction of intradialytic complications [Internet]. *Alexandria Journal of Medicine*. 2022; 58(1):18-30. DOI: [10.1080/20905068.2021.2024349](https://doi.org/10.1080/20905068.2021.2024349)
23. Singh V, Asari V, Rajasekaran R. A Deep Neural Network for Early Detection and Prediction of Chronic Kidney Disease [Internet]. *Diagnostics*. 2022; 12(1):1-22. DOI: [10.3390/diagnostics12010116](https://doi.org/10.3390/diagnostics12010116)
24. Liu H, Wang R. Associations between the serum magnesium and all-cause or cardiovascular mortality in chronic kidney disease and end-stage renal disease patients. A meta-analysis [Internet]. *Medicine*. 2021; 100(45):e27486. DOI: [10.1097/MD.00000000000027486](https://doi.org/10.1097/MD.00000000000027486)
25. Zeng YQ, Qin ZA, Guo ZW. Non- linear relationship between basal serum albumin concentration and cardiac arrest in critically ill patients with end- stage renal disease: a cross-sectional study [Internet]. *BMJ Open*. 2022; 12(2):e051721. DOI: [10.1136/bmjopen-2021-051721](https://doi.org/10.1136/bmjopen-2021-051721)
26. Hong YA, Ban TH, Chae Yeong K, Hwang SD, Choi SR, Lee H, et al. Trends in epidemiology characteristics of end-stage renal disease from 2019 Korean Renal Data System (KORDS) [Internet]. *Kidney Res Clin Pract*. 2021; 40(1):52-61. DOI: [10.23876/j.krcp.20.202](https://doi.org/10.23876/j.krcp.20.202)



Conflictos de interés

Los autores declaran que no existen conflictos de intereses.

Información financiera

Cualquier financiamiento al trabajo, debe ser listado aquí, incluyendo el número, si procede.

Contribuciones de los autores

Conceptualización: *Sergio Orlando Escalona González, Yailé Caballero Mota, Yanela Rodríguez Alvarez, Mirna León Acebo, Zoraida Caridad González Milán, Beatriz Ricardo Páez, Katiuska Danay Rodríguez Espinosa.*

Curación de datos: *Sergio Orlando Escalona González, Zoraida Caridad González Milán, Katiuska Danay Rodríguez Espinosa.*

Análisis formal: *Sergio Orlando Escalona González, Yailé Caballero Mota, Yanela Rodríguez Alvarez.*

Investigación: *Sergio Orlando Escalona González, Zoraida Caridad González Milán.*

Metodología: *Sergio Orlando Escalona González, Yailé Caballero Mota, Yanela Rodríguez Alvarez.*

Administración del proyecto: *Sergio Orlando Escalona González, Zoraida Caridad González Milán.*

Recursos: *Sergio Orlando Escalona González, Yailé Caballero Mota, Yanela Rodríguez Alvarez, Mirna León Acebo, Zoraida Caridad González Milán, Beatriz Ricardo Páez, Katiuska Danay Rodríguez Espinosa.*

Supervisión: *Sergio Orlando Escalona González, Yailé Caballero Mota, Yanela Rodríguez Alvarez, Zoraida Caridad González Milán.*

Validación: *Sergio Orlando Escalona González, Yailé Caballero Mota, Yanela Rodríguez Alvarez, Mirna León Acebo, Zoraida Caridad González Milán.*

Visualización: *Sergio Orlando Escalona González, Yailé Caballero Mota, Yanela Rodríguez Alvarez, Mirna León Acebo, Zoraida Caridad González Milán, Beatriz Ricardo Páez, Katiuska Danay Rodríguez Espinosa.*



Redacción - borrador original: *Sergio Orlando Escalona González, Yailé Caballero Mota, Yanela Rodríguez Alvarez, Mirna León Acebo, Zoraida Caridad González Milán, Beatriz Ricardo Páez, Katiuska Danay Rodríguez Espinosa.*

Redacción – revisión y edición: *Sergio Orlando Escalona González, Yailé Caballero Mota, Yanela Rodríguez Alvarez, Mirna León Acebo, Zoraida Caridad González Milán, Beatriz Ricardo Páez, Katiuska Danay Rodríguez Espinosa.*

Disponibilidad de datos

Archivo complementario: Base de datos de investigación. IBM SPSS v.20.